

16. Bayesov klasifikator II

Strojno učenje 1, UNIZG FER, ak. god. 2021./2022.

Jan Šnajder, natuknice s predavanja, v1.4

1 Bayesov klasifikator vs. logistička regresija

- Ideja: pokazati da logistička regresija i Bayesov klasifikator izračunavaju isti $P(y|\mathbf{x})$
- Model **logističke regresije**:

$$h(\mathbf{x}; \mathbf{w}) = P(y = 1|\mathbf{x}) = \sigma(\mathbf{w}^T \mathbf{x})$$

- Aposteriorna vjerojatnost za **kontinuirani Bayesov klasifikator** (za dvije klase):

$$\begin{aligned} P(y = 1|\mathbf{x}) &= \frac{p(\mathbf{x}|y = 1)P(y = 1)}{p(\mathbf{x}|y = 1)P(y = 1) + p(\mathbf{x}|y = 2)P(y = 2)} = \frac{1}{1 + \frac{p(\mathbf{x}|y=2)P(y=2)}{p(\mathbf{x}|y=1)P(y=1)}} = \\ &= \frac{1}{1 + \exp\left(\ln \frac{p(\mathbf{x}|y=2)P(y=2)}{p(\mathbf{x}|y=1)P(y=1)}\right)} = \frac{1}{1 + \exp(-\alpha)} = \sigma(\alpha) \end{aligned}$$


gdje

$$\alpha = \ln \frac{p(\mathbf{x}|y = 1)P(y = 1)}{p(\mathbf{x}|y = 2)P(y = 2)} = \underbrace{\ln p(\mathbf{x}|y = 1)P(y = 1)}_{h_1(\mathbf{x})} - \underbrace{\ln p(\mathbf{x}|y = 2)P(y = 2)}_{h_2(\mathbf{x})}$$

- Možemo li α prikazati kao linearnu kombinaciju težina, $\alpha = \mathbf{w}^T \mathbf{x}$?
- Da, ako pretpostavimo **dijeljenu kovarijacijsku matricu**:

$$\begin{aligned} \alpha &= h_1(\mathbf{x}) - h_2(\mathbf{x}) \\ &= \mathbf{x}^T \underbrace{\Sigma^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)}_{\mathbf{w}} - \underbrace{\frac{1}{2}\boldsymbol{\mu}_1^T \Sigma^{-1} \boldsymbol{\mu}_1 + \frac{1}{2}\boldsymbol{\mu}_2^T \Sigma^{-1} \boldsymbol{\mu}_2 + \ln \frac{P(y = 1)}{P(y = 2)}}_{w_0} = \mathbf{w}^T \mathbf{x} + w_0 \end{aligned}$$

\Rightarrow logistička regresija istovjetna je Bayesovom klasifikatoru s dijeljenom Σ



- Broj parametara: $\frac{n}{2}(n+1) + 2n + 1$ (Bayes) vs. $n + 1$ (logistička regresija)
 \Rightarrow diskriminativan model daje istu predikciju, ali s manje parametara

2 Naivan Bayesov klasifikator

- $\mathbf{x} = (x_1, \dots, x_n)$ ima $\prod_{k=1}^n K_k$ mogućih vrijednosti
- $p(\mathbf{x}|y)$ kao kategorička razdioba od $\mathbf{x} \Rightarrow$ **previše parametara i nema generalizacije**
- Pojednostavljenje uvođenjem **induktivnih pretpostavki** u obliku uvjetnih nezavisnosti
- Pretpostavka: u svakoj klasi, svaka značajka uvjetno je nezavisna od svih drugih:

$$x_k \perp (x_1, \dots, x_{k-1}) | y \Leftrightarrow P(x_k | x_1, \dots, x_{k-1}, y) = P(x_k | y)$$

- Faktorizacija uz tu pretpostavku:

$$P(x_1, \dots, x_n | y) = \prod_{k=1}^n P(x_k | x_1, \dots, x_{k-1}, y) = \prod_{k=1}^n P(x_k | y)$$

- **Naivan Bayesov klasifikator** (*Naïve Bayes classifier*):

$$h(x_1, \dots, x_n) = \operatorname{argmax}_j P(y = j) \prod_{k=1}^n P(x_k | y = j)$$

- Procjena parametara – MLE za $P(y)$ i MAP za $P(\mathbf{x}|y)$:

$$P(y = j) = \hat{\mu}_j = \frac{1}{N} \sum_{i=1}^N \mathbf{1}\{y^{(i)} = j\} = \frac{N_j}{N}$$

$$P(x_k | y = j) = \hat{\mu}_{k,j} = \frac{\sum_{i=1}^N \mathbf{1}\{x_k^{(i)} = x_k \wedge y^{(i)} = j\} + 1}{\sum_{i=1}^N \mathbf{1}\{y^{(i)} = j\} + K_k} = \frac{N_{kj} + 1}{N_j + K_k}$$

gdje je N_j broj primjera u klasi j , a N_k broj vrijednosti značajke k

- Broj parametara: $\sum_{k=1}^n (K_k - 1) \cdot K + K - 1$
- Pretpostavka uvjetne nezavisnosti uglavnom ne vrijedi, no model u praksi radi dobro

3 Uvjetna nezavisnost

- **Uvjetna nezavisnost** X i Y uz dani Z – notacija: $X \perp Y | Z$:

$$P(X, Y | Z) = P(X | Z)P(Y | Z)$$

$$P(X | Y, Z) = P(X | Z)$$

$$P(Y | X, Z) = P(Y | Z)$$

4 Polunaivan Bayesov klasifikator

- Ideja: **združiti** (ne faktorizirati) varijable koje nisu uvjetno nezavisne

- Npr., ako $x_2 \perp x_3 | y$:

$$P(x_1, x_2, x_3, y) = P(x_1 | y)P(x_2, x_3 | y)P(y)$$

⇒ slabije pretpostavke ⇔ složeniji model ⇔ više parametara

- Broj mogućih združivanja ⇔ broj particija n -članog skupa ⇔ **Bellov broj** B_n
- Previše kombinacija ⇒ **heurističko pretraživanje** na temelju **kriterija združivanja**
- Dva pristupa:
 - **točnost modela** (unakrsna provjera) – algoritam FSSJ
 - **procjena zavisnosti varijabli** – algoritmi TAN i k -DB

Algoritam FSSJ

1. Inicijaliziraj $X = \emptyset$. Početna faktorizacija:

$$P(x_1, \dots, x_n, y) = P(x_1) \cdots P(x_n)P(y)$$

$$P(y | x_1, \dots, x_n) = P(y)$$

Klasificiraj primjere iz skupa za provjeru: $y^* = \operatorname{argmax}_j P(y = j)$

2. Za svaku varijablu $x_i \notin X$ koja još nije uključena u model, razmotri:
 - (a) Uključi x_i kao uvjetno nezavisnu u odnosu na ostale varijable za danu klasu j
 - (b) Uključi x_i tako da se ona doda u zajednički faktor s nekom već uključenom varijablom
3. Izaberi x_i i opciju koja minimizira pogrešku generalizacije
4. Ponavljaaj od koraka (2) do konvergencije pogreške

- **Uzajamna informacija** – zavisnost varijabli kao odstupanje $P(x, y)$ od $P(x)P(y)$:

$$I(x, y) = D_{\text{KL}}(P(x, y) || P(x)P(y)) = \sum_{x, y} P(x, y) \ln \frac{P(x, y)}{P(x)P(y)}$$

$$\Rightarrow I(x, y) = 0 \Leftrightarrow x \perp y, I(x, y) > 0 \Leftrightarrow x \not\perp y$$

- $D_{\text{KL}}(P || Q)$ – **Kullback-Leiblerova divergencija** (odstupanje) distribucije P od Q :

$$D_{\text{KL}}(P || Q) = \sum_x P(x) \ln \frac{P(x)}{Q(x)}$$

$$\Rightarrow \text{relativna entropija } P(x) \text{ u odnosu na } Q(x)$$